

O IMPACTO DAS TECNOLOGIAS DIGITAIS NA EFICÁCIA DA MANUTENÇÃO
PREDITIVA INDUSTRIAL

THE IMPACT OF DIGITAL TECHNOLOGIES ON MAINTENANCE EFFECTIVENESS
INDUSTRIAL PREDICTIVE

Elias Aoad Neto ^{1, i}
Thiago Tadeu Amici ^{2, ii}
Daniel Camusso ^{3, iii}
Daniel Otávio Tambasco Bruno ^{4, iv}

Data de submissão: (04/08/2022) Data de aprovação: (22/01/2023)

RESUMO

A Transformação Digital é uma realidade na nova geração de ambientes industriais, permitindo ganhos expressivos em produtividade, qualidade e integração de setores. A colaboração entre a intervenção humana, máquinas e sistemas, faz com que os esforços para obter um ambiente com decisões assertivas sejam mais explorados e confiáveis. A aplicação desse conceito na indústria soluciona grande parte dos impasses na gestão da manutenção, possibilitando a implementação de itens de tecnologia que fornecem informações em tempo real, acesso remoto aos dados e a análise estatística automatizada com a aplicação de ferramentas de *Machine Learning (ML)*, adotando tecnologias até então desconhecidas das equipes industriais. O objetivo desse artigo é demonstrar a aplicação avançada e os resultados alcançados por uma plataforma de monitoramento inteligente da manutenção preditiva industrial, que integra Internet das Coisas Industrial (IIoT), banco de dados em nuvem ou em servidores locais, aplicativos para dispositivos móveis Android e análise automatizada com algoritmos desenvolvidos em linguagem *Python*. A utilização da plataforma foi analisada em implementações reais em indústrias e os resultados são discutidos em cada caso.

Palavras-chave: Transformação Digital; Manutenção Preditiva; Internet Industrial das Coisas; Machine Learning; Banco de Dados.

ABSTRACT

Digital Transformation is a reality in the new generation of industrial environments, allowing for significant gains in productivity, quality and integration of sectors. The collaboration

¹ Engenheiro de Controle e Automação e Pós-graduando em MBA - Gestão de Projetos Aplicados a Inovação em Indústria 4.0 na Faculdade SENAI de Tecnologia Mecatrônica. E-mail: ntaoad@me.com

² Mestre em Automação e Controle de Processos da Faculdade SENAI de Tecnologia Mecatrônica. E-mail: thiago.amici@sp.senai.br

³ Mestrando e Especialista em Indústria 4.0 e Engenharia automobilística. Docente da Faculdade SENAI de Tecnologia Mecatrônica. E-mail: daniel.camusso@sp.senai.br

⁴ Mestre em Engenharia da Informação. Professor da Faculdade SENAI de Tecnologia Mecatrônica. E-mail: daniel.bruno@sp.senai.br

between human intervention, machines and systems, makes efforts to obtain an environment with assertive decisions more explored and reliable. The application of this concept in the industry solves most of the deadlocks in maintenance management, enabling the implementation of technology items that provide real-time information, remote access to data and automated statistical analysis with the application of Machine Learning (ML) tools, adopting technologies until then unknown to industrial teams. The purpose of this article is to demonstrate the advanced application and results achieved by an intelligent monitoring platform for industrial predictive maintenance, which integrates the Industrial Internet of Things (IIoT), databases in the cloud or on local servers, applications for Android mobile devices and automated analysis with algorithms developed in Python language. The use of the platform was analyzed in real implementations in industries and the results are discussed in each case.

Keywords: Digital Transformation; Predictive Maintenance; Industrial Internet of Things; Machine Learning; Database.

1 INTRODUÇÃO

A gestão eficiente das atividades de manutenção impacta diretamente nos resultados industriais, reduzindo perdas por paradas de produção, baixa produtividade e custos extras na recuperação desses índices.

Dentre os fatores ligados a este resultado, pode-se definir a manutenção como uma das atividades mais impactantes na produtividade e nos custos operacionais controláveis nas indústrias. É também uma função crítica do negócio que impacta no risco comercial, na produtividade, na qualidade do produto, no custo de produção, na segurança e no desempenho ambiental. Por essas razões, a manutenção é considerada nas boas práticas da indústria, não apenas como um custo a ser evitado, mas juntamente com a engenharia de confiabilidade e a aplicação de tecnologias digitais, como uma função de negócio de alta alavancagem.

Os custos de manutenção representam 4% do Produto Interno Bruto (PIB) no Brasil, segundo dados da Associação Brasileira de Manutenção (ABRAMAN, 2013). Na primeira década dos anos 2000, época em que o PIB chegou a crescer 7,6% ao ano, a produtividade média anual do país avançou apenas 1,4%. Atualmente, esses problemas são resolvidos utilizando sistemas independentes, mas geram poucas tomadas de decisão utilizando previsões de ocorrências futuras. Ainda são muito utilizados os relatórios em papel, estatísticas em planilhas e sistemas *Enterprise Resource Planning (ERP)* complexos.

A baixa produtividade brasileira por décadas pode ser explicada por fatores estruturais, pouca capacidade de incorporar tecnologias e baixa qualidade na capacitação profissional. Conforme Otani e Machado (2008):

Recomenda-se que todo equipamento crítico, ou seja, aquele cuja falha interromperia ou pararia a produção, aumentaria os custos de energia ou ainda traria grandes problemas para o controle de segurança, deve ser “coberto” por um sistema de manutenção preditiva. (OTANI e MACHADO, 2008, p. 13).

Um dos dilemas enfrentados pelos gestores de manutenção é a escassez de recursos financeiros e de pessoal qualificado, fazendo com que manter a fábrica funcionando seja um desafio, e mais difícil ainda, seja encontrar maneiras para melhorar a confiabilidade.

Outro ponto ressaltado está ligado às boas práticas em Gestão de Projetos, observando que segundo o *Project Management Body Of Knowledge* (PMBOK): “Projeto é um esforço temporário empreendido para criar um produto, serviço ou resultado exclusivo.” (PMI, 2017). Esse conceito define com similaridade algumas tarefas executadas pela manutenção industrial, quando nos referimos às melhorias, implementações tecnológicas e modificações de máquinas e processos produtivos, realizadas pelos técnicos e engenheiros de manutenção.

As empresas brasileiras têm avançado rumo a Indústria 4.0, buscando soluções que alinhem os conceitos de mobilidade no chão de fábrica, IIoT, *Cloud Computing*, *Big Data* e Inteligência Artificial. Com essa integração, as ocorrências de manutenção podem ser obtidas em tempo real, acessíveis para análise via Internet e vinculadas a uma previsão futura através de algoritmos de ML e de um histórico de dados consolidado.

O objetivo desse artigo é descrever as etapas do desenvolvimento dos hardwares e softwares de um sistema com características relevantes para a gestão da manutenção, e a implementação de tecnologias capazes de realizar estas atividades, tais como: gerar relatórios *online* de manutenção corretiva; programar com periodicidade variável as manutenções preventivas, utilizar código de barras bidimensional *Quick Response (QR) Code* na identificação de tarefas e no local de manutenção; acompanhar os índices *Mean Time Between Failures* (MTBF), ou Tempo Médio entre Falhas, e o *Mean Time To Repair* (MTTR), ou Tempo Médio para Reparo, e a disponibilidade do equipamento; monitorar em tempo real variáveis sensorizadas com IIoT em pontos críticos das máquinas; alertar ocorrências por limites, tendências e anormalidade nos dados coletados, entre outras funções que compõe as ferramentas de *Machine Learning*; notificar eventos via e-mails; disponibilizar dados em aplicativo móveis *Android* e mostrar informações em *dashboards* para os usuários cadastrados no sistema.

Esse artigo está dividido em cinco seções, na qual a segunda apresenta a revisão de literatura que fundamenta o artigo, a terceira apresenta a metodologia e a descrição dos programas e testes elaborados, a quarta apresenta os resultados obtidos, as estimativas de custos e as análises de resultados e na quinta são apresentadas as considerações finais.

2 REVISÃO DE LITERATURA

2.1 Internet das Coisas Industrial (IIoT)

A Revolução Industrial 4.0 é um dos principais impulsionadores da adoção massiva da Internet das Coisas (IoT) no setor industrial, aumentando a produtividade e o impacto econômico no setor manufatureiro. Conforme citado por Otani e Machado (2008): “Monitoração contínua é o acompanhamento *online* das variáveis dos equipamentos através dos sensores implantados neles”.

A implementação bem-sucedida de uma solução baseada em IIoT envolve muitos aspectos, incluindo: alocação de infraestrutura adequada para coleta precisa de dados de vários sensores; agregação de dados em *gateways* conectados à rede; desenvolvimento e adoção de algoritmos avançados de ML; e hospedagem de tarefas relacionadas a ML na computação de borda com o objetivo de reduzir a carga da rede.

A IIoT conecta o mundo físico dos dispositivos “reais” e o mundo digital, expandindo as possibilidades da tecnologia da informação dentro das empresas, e integrando sensores e atuadores para monitorar e controlar as “coisas”. (ALABADI; HABBAL e WEI, 2022, tradução

nossa).

Logo, aquisição e processamento de dados, além da tomada de decisão inteligente são os benefícios que os sistemas IIoT trazem para os ambientes industriais.

Conforme Otani e Machado (2008):

Em termos práticos, uma técnica de manutenção preditiva deve atender aos seguintes requisitos: permitir a coleta de dados com o equipamento em funcionamento, ou com o mínimo de interferência possível no processo de produção; e permitir a coleta dos dados que possibilitem a análise de tendência. (OTANI e MACHADO, 2008, p. 9).

2.2 Sistemas de Gestão de Banco de Dados

A Internet das Coisas (IoT) traz novos desafios aos Sistemas de Gerenciamento de Banco de Dados (SGBD), pois introduz grandes quantidades de dados de sensores usados em nossas vidas diárias. Esses sensores geram uma grande quantidade de dados heterogêneos que devem ser processados pelo SGBD correspondente. Os SGBDs podem ser categorizados em dois tipos principais: SGBDs relacionais e SGBDs não relacionais (EYADA et al., 2020, tradução nossa).

A tecnologia IoT é agora a espinha dorsal de muitas indústrias, com a integração de sistemas de controle industrial, monitoramento de variáveis de máquinas e de produtividade industrial. As tecnologias de IoT geram grandes quantidades de dados heterogêneos, como texto, números, sons, vídeos e imagens. Esses tipos de dados devem ser transmitidos, processados e armazenados na nuvem ou em servidores locais. Além disso, ele deve ser referenciado e atualizado conforme necessário.

Armazenar e gerenciar com eficiência grandes quantidades de dados de IoT é um dos principais desafios para os arquitetos de infraestrutura de Tecnologia da Informação (TI). O SGBD é o software responsável por armazenar e gerenciar bancos de dados, e o tipo relacional é o sistema mais amplamente utilizado. Eles são baseados nos modelos que usam *Structured Query Language* (SQL) como sua linguagem de interface de programação.

2.3 Plataforma de computação em nuvem

A computação em nuvem é um modelo de computação que permite que os recursos sejam provisionados com base nas necessidades do cliente (ASHKATORAB; TAGHIZADEH e ZAMANIFAR, 2012, tradução nossa). É um modelo de consumo e entrega de serviços de computação baseado em consumo, que permite a entrega em tempo real de recursos de computação configuráveis (redes, servidores, armazenamento etc.).

Esses recursos são altamente escaláveis, disponibilizados por muitos fornecedores diferentes e usados por várias empresas que são clientes das plataformas. Os serviços são contratados conforme necessidade e são pagos pela utilização. Os mais utilizados são categorizados em três tipos: *Software as a Service (SaaS)*, *Platform as a Service (PaaS)* e *Infrastructure as a Service (IaaS)*.

Para aplicativos relacionados ao uso industrial de IoT, o PaaS e o IaaS são as opções mais populares. Elas fornecem ambientes integrados para construção, teste e implantação de aplicativos avançados. Os aplicativos criados, ou suportados por um provedor de nuvem, são implantados em infraestrutura gerenciável. Os clientes têm controle dos aplicativos, serviços

e configurações no ambiente de hospedagem de aplicativos. Um exemplo de *IaaS* é o serviço de *Virtual Machines* (VMs) na *Microsoft Azure* e de *PaaS* é o *Simple Storage Service* (S3) na *Amazon Web Service* (AWS), entre outros.

2.4 Machine Learning

Um subcampo da Ciência da Computação, a Inteligência Artificial (IA) se concentra no desenvolvimento de programas de computador e máquinas que podem executar tarefas nas quais os humanos são naturalmente bons, como entender a linguagem natural, realizar cálculos estatísticos e reconhecer imagens (LINS e GIVIGI, 2022, tradução nossa).

Em meados do século 20, o Aprendizado de Máquina, ou *Machine Learning* (ML), surgiu como um subconjunto da IA inspirado em estudos conceituais de como o cérebro humano funciona, e estabeleceu novas direções para o design de IA. Hoje, o ML é frequentemente visto como um campo científico focado em projetar modelos e algoritmos de computador que podem executar tarefas específicas por reconhecimento de padrões, sem necessidade de programação explícita.

Uma das principais ideias e motivações por trás do diversificado e fascinante campo da programação de computadores é a automação de tarefas tediosas (RASCHKA; PATTERSON e NOLET, 2022, tradução nossa). No entanto, desenvolver um conjunto de regras que possa executar essa tarefa de forma confiável, incorporado em um programa de computador, é muitas vezes tedioso e muito difícil.

Nesse contexto, o ML pode ser utilizado na pesquisa e desenvolvimento para automatizar a tomada de decisões complexas. Atualmente, a linguagem *Python* se tornou muito popular na comunidade da Ciência da Computação e as modernas bibliotecas de *ML* e, *Deep Learning* (Aprendizado Profundo), agora são baseadas em *Python*.

3 METODOLOGIA

O desenvolvimento prático das tecnologias descritas nesse artigo foi executado para estar alinhado com alguns pilares fundamentais da Indústria 4.0. Dentre os pilares envolvidos no projeto estão: Internet da Coisas Industrial (IIoT), *Big Data & Analytics*, Computação em Nuvem, Inteligência Artificial, Integração de Sistemas e *Cybersecurity*.

O desafio tecnológico descrito neste artigo foi concretizado na prática através do desenvolvimento de uma plataforma inteligente de gestão de manutenção, composta pela aplicação integrada das tecnologias descritas na revisão de literatura, possibilitando a coleta de dados de valores em sensores, armazenamento histórico desses dados, visualização das informações dos dados em formatos gráficos de interfaces de usuário e a análise estatística automatizada nas ferramentas de *ML*.

Usando um *gateway IIoT* de projeto proprietário, os sinais são coletados de sensores analógicos e digitais, dimensionados individualmente em cada aplicação, para monitorar continuamente as atividades nas máquinas produtivas sensorizadas.

Os dados coletados são armazenados em um Banco de Dados (BD) relacional SQL, para a construção de uma base de dados histórica, possibilitando uma futura correlação entre esses dados coletados e outros dados que tenham sido armazenados em outro BD SQL.

A visualização dos dados em tempo real pode ser feita em computadores ou dispositivos móveis, através das aplicações desenvolvidas, transformando a situação anormal

Considerando que o projeto deve atender aplicações industriais, foi adotado um microcontrolador PIC, devido ao seu desempenho mais rápido, proporcionado pela arquitetura *Reduced Instruction Set Computer* (RISC). Além disso, seu consumo de energia é menor, sua programação é mais fácil e possui interface de entradas analógicas integradas, sem precisar de circuito extra.

Já para a interface de conectividade Wi-Fi, foi adotado o *hardware* de modelo ESP8266, fabricado pela empresa *Espressif*. No quadro 1 são descritos os requisitos técnicos mais relevantes para a escolha desses componentes no projeto *IIoT*.

Quadro 1 – Características técnicas dos principais componentes eletrônicos

Microcontrolador Série: PIC18(L)Fxx50	Módulo Wi-Fi: ESP8266 ESP-12F
Núcleo: PIC	Wireless padrão 802.11 b/g/n
Resolução ADC: 10 bit	Antena embutida
Número de I/Os: 35 I/O	Portas GPIO: 11
Tensão alimentação operacional: 2 ~ 5.5 V	Tensão de operação: 4,5 ~ 9V
Temperatura operacional mínima: - 40 C	Taxa de transferência: 110-460800bps
Temperatura operacional máxima: + 85 C	Conversor analógico digital (ADC)

Fonte: Elaborado pelo autor

Um elemento importante considerado nesse projeto foi a segurança nas redes industriais. Apesar desse tópico ser extenso e controverso, procuramos preservar no *hardware* a capacidade única de ler os valores dos sensores conectados, sem habilitar a escrita de valores em atuadores das máquinas (XU et al., 2018, tradução nossa).

3.2 Etapa 2 – Configuração do servidor em nuvem Microsoft AZURE

As capacidades presentes nas plataformas de computação em nuvem foram fator decisivo na escolha desse modelo para a hospedagem da aplicação *web*. Dentre essas estão a alta elasticidade, capaz de absorver uma demanda pontual e momentânea de processamento dos dados, e a alta escalabilidade, que permite o aumento rápido da capacidade da máquina virtual em processamento, memória, armazenamento etc.

O ambiente de criação de servidores em nuvem, proporciona as condições ideais para que a aplicação seja facilmente implantada, conforme mostra a Figura 4.

Figura 4 – Grupo de recursos da plataforma Azure utilizados no ambiente em nuvem

Diretório Padrão (techautomatsmart.onmicrosoft.com)

+ Criar ⚙ Gerenciar a exibição ↻ Atualizar ↓ Exportar para CSV 🔍 Abrir a consulta 🏷 Atribuir marcações

Filtrar por qualquer ca... Assinatura igual a **tudo** Localização igual a **tudo** + Adicionar filtro

0 Recursos não seguro 0 Recomendações

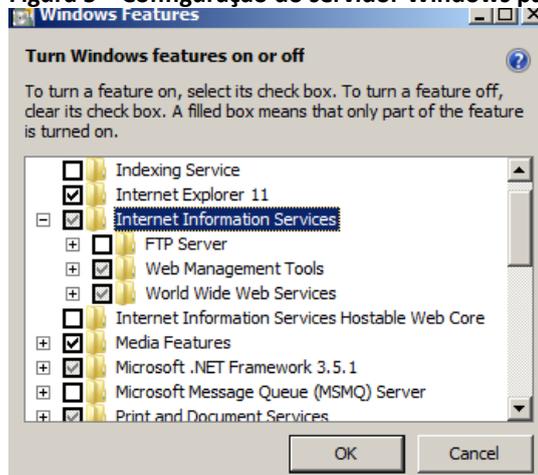
<input type="checkbox"/> Nome ↑↓	Assinatura ↑↓
<input type="checkbox"/> cloud-shell-storage-eastus	A.Tech
<input type="checkbox"/> MaquinasVirtuais	A.Tech
<input type="checkbox"/> MaquinasVirtuaisDev	A.Tech
<input type="checkbox"/> MaquinaVirtual	A.Tech

Fonte: Elaborada pelo autor

Na criação da Máquina Virtual (VM – *Virtual Machine*) foi utilizado o sistema operacional *Windows Server*, com um endereço de *Internet Protocol* (IP) fixo, já que as comunicações entre o IIoT e o servidor necessitavam de endereços que não sofressem alteração para o envio dos dados coletados. Nesta VM, além do *Web Server*, foi instalado o banco de dados, permitindo a consulta aos dados armazenados através de um endereço *Hyper Text Transfer Protocol Secure* (HTTPS), seguindo os mesmos critérios dos endereços seguros utilizados na Internet. Para as configurações de processador e memória não havia necessidade de alta capacidade, logo foram utilizadas as configurações básicas de VM da Microsoft Azure. Quando havia necessidade de uma máquina com melhor performance, era solicitado para a Microsoft Azure o incremento na VM.

Em cada servidor foram necessárias configurações que disponibilizavam o serviço *Internet Information Services* (IIS) do Windows, conforme a mostra a Figura 5.

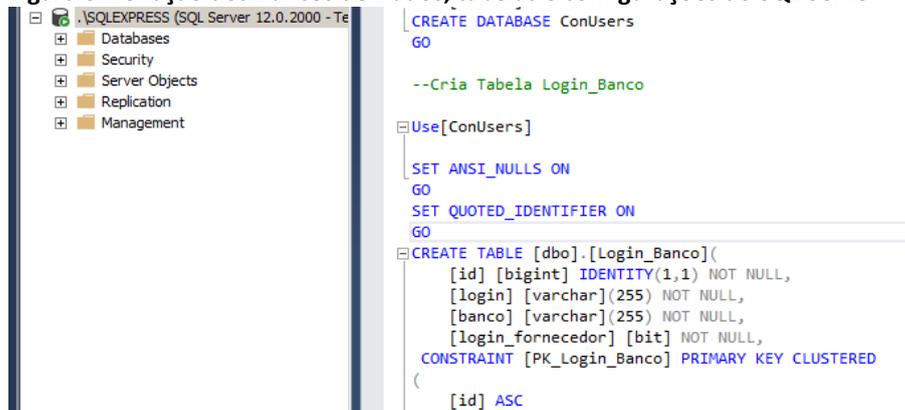
Figura 5 – Configuração do servidor Windows para ser provedor de serviços de Internet



Fonte: Elaborada pelo autor

O Microsoft *SQL Server*, mostrado na figura 6, foi o Sistema de Gerenciamento de Banco de Dados (SGBD) escolhido para o projeto. Ele utiliza a tecnologia de banco de dados relacional compatível com todas as aplicações desenvolvidas. Foram desenvolvidos *scripts* de criação automática dos bancos de dados, para cada sistema individual criado, fazendo com que a criação das estruturas das tabelas, configurações, permissões entre outros, fossem implementadas, em todos os casos, com as mesmas características.

Figura 6 – Criação dos Bancos de Dados, tabelas e configurações do SQL Server



Fonte: Elaborada pelo autor

3.3 Etapa 3 – Desenvolvimento do aplicativo Android

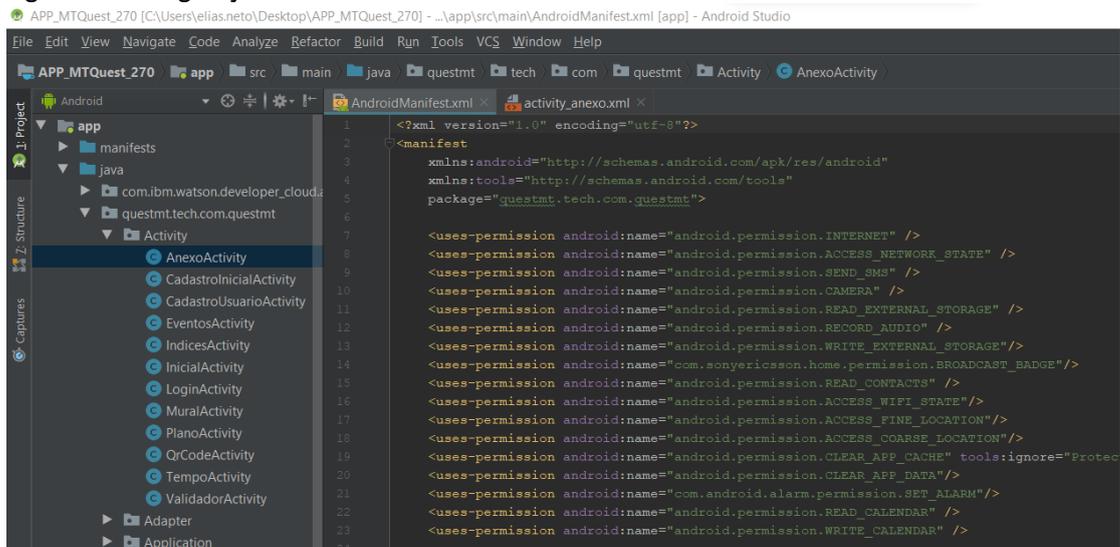
Os dispositivos móveis conectados a um sistema centralizado, permitem a atualização dos dados e a sincronização do conteúdo em todos os dispositivos.

A opção pela tecnologia Android, a mais popular para dispositivos móveis, definiu o Android Studio como o *Integrated Development Environment* (IDE), ou Ambiente de Desenvolvimento Integrado, oficial para a criação do aplicativo. Além do editor de código e das ferramentas de desenvolvedor avançadas, o Android Studio oferece recursos nativos na criação de *apps* Android.

Cada projeto no Android Studio contém um ou mais módulos com arquivos de código-fonte e de recursos, e cada módulo de *app* contém as pastas a seguir:

- Manifests*: contém o arquivo `AndroidManifest.xml`, que atribui as permissões do sistema, conforme mostra a figura 7;
- Java: contém os arquivos de código-fonte do Java, incluindo o código de teste do JUnit, que é o nome de um *framework open-source* para construção de testes automatizados em Java;
- Recursos: contém todos os recursos que não são código, como layouts XML, *strings* de Interface de Usuário (IU) e imagens em *bitmap*.

Figura 7 – Configuração do `AndroidManifest.xml`



Fonte: Elaborada pelo autor

Desenvolver projetos de aplicativos torna necessária a criação de inúmeros elementos de programação, dentre eles a configuração do sistema operacional que vai rodar a aplicação, a importação de bibliotecas terceiras para utilização de funções específicas, a elaboração de telas de interface do usuário com elementos gráficos funcionais e a integração de cada uma das ações, ou funções, do aplicativo móvel com o servidor central dos dados.

No quadro 2 são mostradas as versões dos ambientes de programação e bibliotecas utilizadas.

Quadro 2 – Informações do IDE do Android Studio

Android Studio 3.1.2
Build #AI-173.4720617, built on April 13, 2018
JRE: 1.8.0_152-release-1024-b02 amd64
JVM: OpenJDK 64-Bit Server VM by JetBrains s.r.o
Windows 10 10.0

Fonte: Elaborado pelo autor

O aplicativo desenvolvido e descrito nesse artigo, utilizou como base a versão do *Software Development Kit* (SDK) Android número 23, mostrado na figura 8, para ser usado no desenvolvimento de aplicativos para Android 6.0 *Marshmallow*, possibilitando a utilização em dispositivos mais antigos.

Figura 8 – Requisitos de versão de bibliotecas e sistema operacional

Fonte: Elaborada pelo autor

A navegação e ambiente de IU da aplicação móvel foi pensada priorizando acessos rápidos e pouco complicados. Dentre as funcionalidades desenvolvidas, mostradas na figura 9, pode-se destacar:

- Tela de inicialização da aplicação (1);
- Tela de entrada das credenciais de acesso ao sistema (2);
- Configurações iniciais de conectividade com o servidor (3);
- Tela principal com as opções de navegação do *app* (4);
- Tela para preenchimento das ocorrências de manutenção corretiva (5);
- Tela de revisão dos dados e inclusão de anexos para o envio ao servidor (6);
- Tela para carregar as atividades programadas e ler os *QR Code* nas máquinas, com o *link* para a execução da atividade programada (7);
- Tela de visualização do banco de dados local *SQLite*, sem necessidade de estar sincronizado com o servidor (8).

Figura 9 – Fluxograma de telas desenvolvidas para a aplicação Android



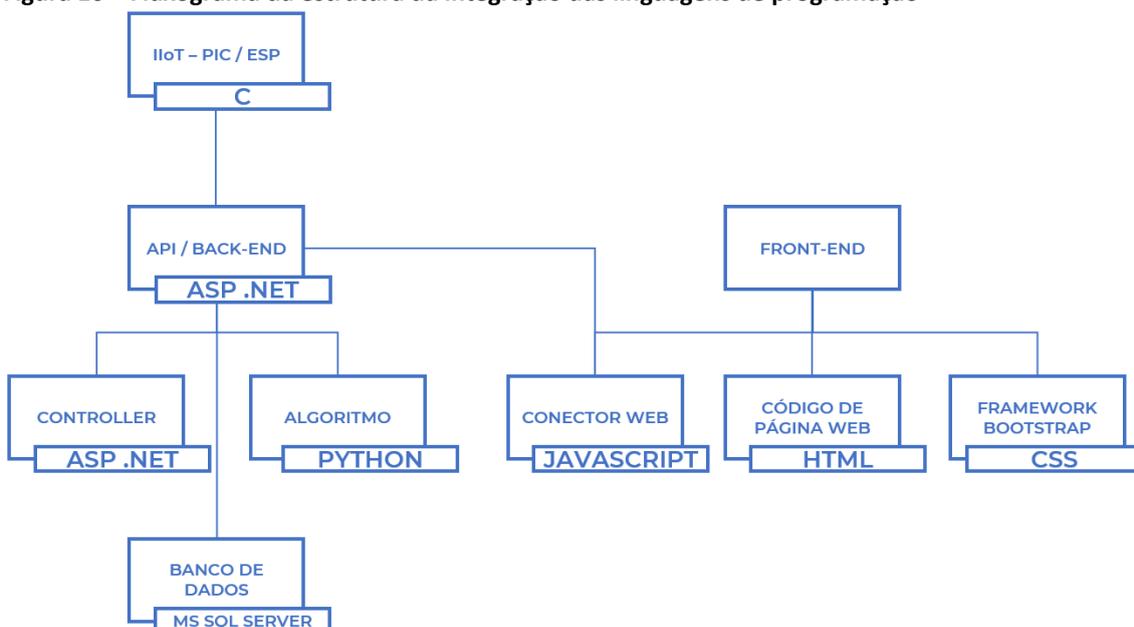
Fonte: Elaborada pelo autor

3.4 Etapa 4 – Desenvolvimento do ambiente *web* de interface do usuário

Para o desenvolvimento do projeto da aplicação *web*, foram adotadas tecnologias Microsoft, por suas características de integração e apoio aos softwares durante o projeto. As linguagens de programação adotadas foram escolhidas conforme a tarefa a ser executada, de acordo com o resultado em performance e integração pretendidos.

O desenvolvimento *web* é normalmente dividido em: *Back-End*, que trata das regras de manipulação dos dados, e *Front-End*, que trata das regras da interface com o usuário. Na figura 10, é mostrado um fluxograma com as relações e linguagens utilizadas.

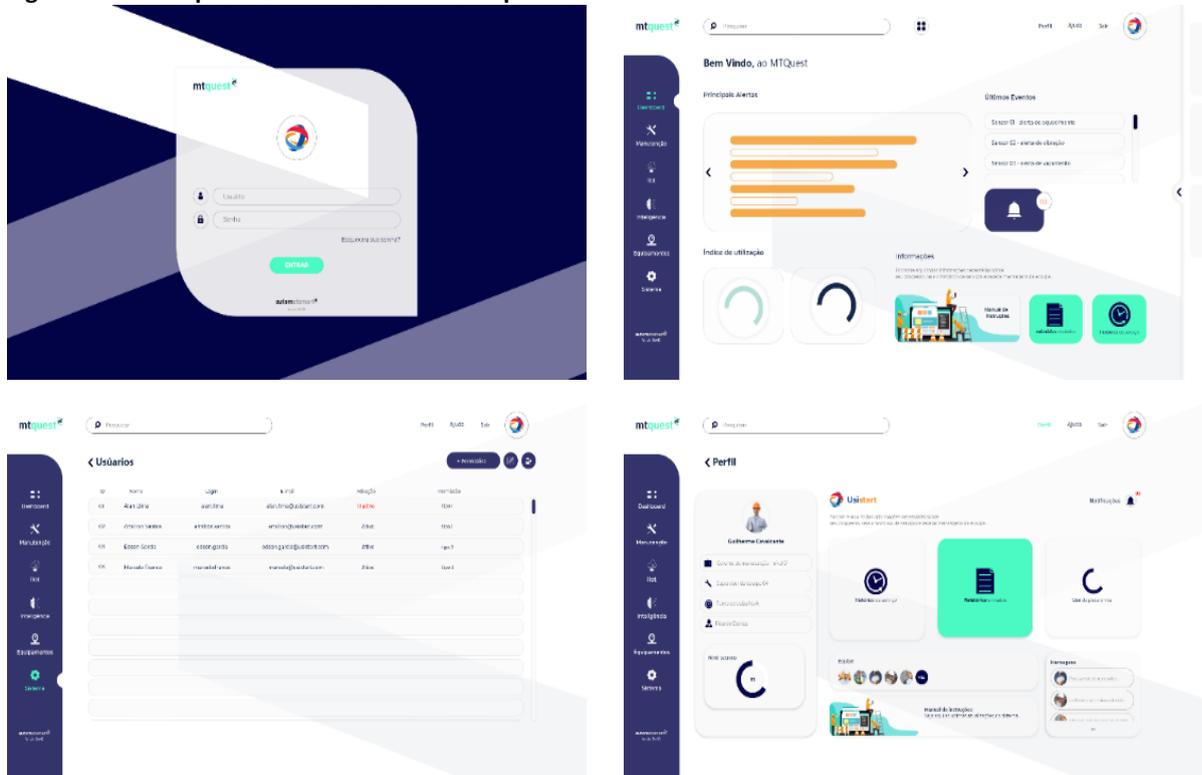
Figura 10 – Fluxograma da estrutura da integração das linguagens de programação



Fonte: Elaborada pelo autor

É importante ressaltar que as interfaces, mostradas na figura 11, foram feitas pela equipe de Design Integrado do SENAI 1.23, priorizando a Experiência do Usuário (*UX – User Experience*) e a Experiência do Consumidor (*CX – Customer Experience*), para tornar a usabilidade e a jornada do usuário simples e eficiente.

Figura 11 – Exemplos de telas desenvolvidas para otimizar a interface do usuário



Fonte: Elaborada pelo autor

3.5 Etapa 5 – Desenvolvimento do algoritmo de Machine Learning em Python

No desenvolvimento das ferramentas de análise por algoritmos, utilizando o *Machine Learning* (ML) clássico, foi considerado que o desempenho preditivo dos algoritmos depende em grande parte da engenharia de recursos. Atingir com eficiência a tabulação (estruturação) adequada dos dados, bem como o volume satisfatório que resulte em análises precisas, exige tempo e o modelamento adequado da programação.

Os recursos de ML, usados nesse projeto, foram integrados à aplicação *web* utilizando-se as bibliotecas *Python Scikit-Learn* e *ARIMA*, que fornecem eficiência em modelagem estatística, análise de séries temporais, análise e mineração de dados, e dão suporte ao aprendizado supervisionado e não supervisionado.

Das bibliotecas citadas, foram usados modelos de regressão linear, de classificação, de detecção de anomalias, de séries temporais, dentre outros. Os modelos treinados com uma periodicidade recorrente, eram salvos nos bancos de dados da plataforma, através de uma biblioteca *Python* chamada *Pickle*, usada principalmente na serialização e desserialização de uma estrutura de objeto *Python*.

Na figura 12, pode-se visualizar um exemplo de base de dados utilizado pelo sistema, onde as variáveis, em um instante determinado, armazenaram os valores lidos pelos diferentes sensores instalados nas máquinas.

Figura 12 – Exemplos de valores obtidos pelos sensores instalados nas máquinas

hle_sen_sensores_id	hle_data_leitura	hle_leitura_sensor	hle_leitura_escalada	hdw_equ Equipamentos_id
1	01/12/2018 01:46	0	0	34039
2	01/12/2018 01:46	0	0	34039
3	01/12/2018 01:46	0	0	34039
29	01/12/2018 01:46	0	0	34033
54	01/12/2018 01:46	0	0	34031
55	01/12/2018 01:46	0	0	34031
56	01/12/2018 01:46	0	0	34031
62	01/12/2018 01:46	1155	3582	34023
63	01/12/2018 01:46	1239	5879	34023
67	01/12/2018 01:46	1157	3637	34022
77	01/12/2018 01:46	1158	3664	34001
78	01/12/2018 01:46	1221	5387	34001

Fonte: Elaborada pelo autor

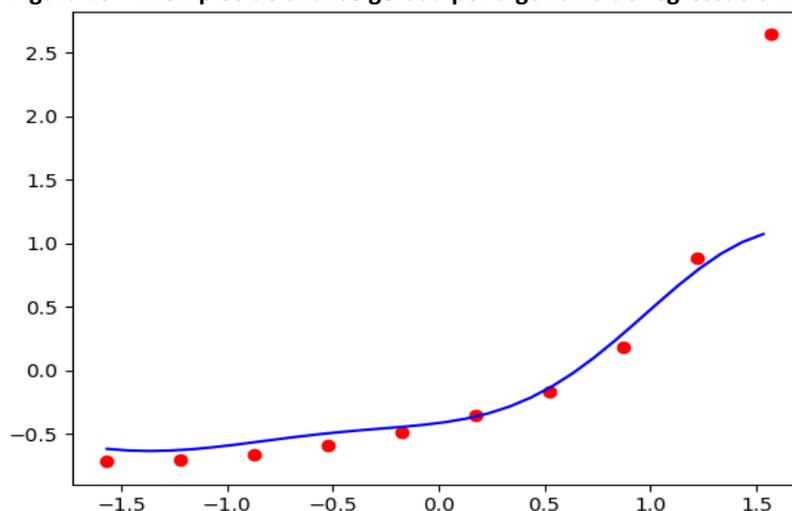
O sistema pode trabalhar com modelos diferentes de *ML*, desenvolvidos sob demanda em cada tipo de aplicação do software no cliente. Serão descritos os três modelos de *ML* que apresentaram os resultados mais assertivos, bem como os exemplos dos problemas envolvidos e as respostas dadas pelas ferramentas de *ML*.

3.5.1 Modelos de Regressão Linear

Nos algoritmos de regressão linear, normalmente busca-se responder perguntas do tipo: “Quantos?” ou “Qual quantidade?”, ou seja, fazer uma previsão do valor futuro.

No exemplo da figura 13, utilizando a IDE Spyder, foram inseridos valores de referência para analisar o comportamento das variáveis utilizando o modelo de regressão *Support Vector Regression* (SVR), para prever o seguinte problema: “Tempo estimado de parada de produção/máquina de acordo com o valor lido pelo sensor”.

Figura 13 – Exemplos de análise gerada por algoritmo de regressão SVR



Fonte: Elaborada pelo autor

No gráfico, o eixo X é o valor lido pelo sensor e o eixo Y é a quantidade de horas de parada de produção. Da interpolação dessas duas variáveis temos os pontos em vermelho, que representam os valores reais utilizados para treinar o algoritmo.

Pode-se verificar que, de acordo com os valores do histórico utilizado para treinar o

algoritmo, somente a partir da leitura do valor 0,5 pelo sensor, é possível visualizar um tempo relacionado de parada de máquina. O resultado apresentado pelo algoritmo é a linha azul, calculada para prever os tempos ainda não coletados em situações reais.

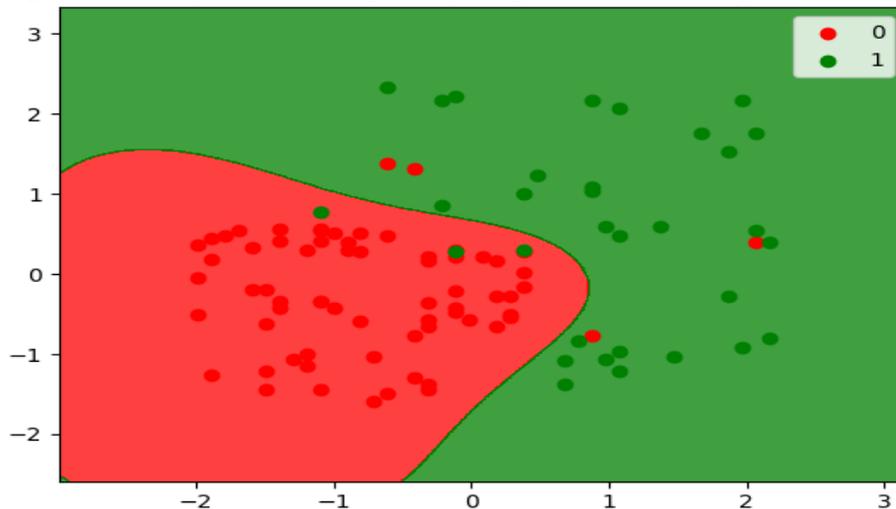
Por exemplo com o sensor lendo um valor de 1,25 prevê-se uma parada de 0,75 horas, respondendo à questão proposta: “Qual quantidade de horas de máquina parada?”.

3.5.2 Modelos de classificação

Nos algoritmos de classificação, procura-se responder a perguntas do tipo: “Isto é A ou B?”, ou “Isto é Sim ou Não?”, ou “Isto é Verdadeiro ou Falso?”.

No exemplo da figura 14, foram utilizados valores de referência para analisar o comportamento das variáveis utilizando classificação *Kernel Support Vector Machine* (SVM), para prever o problema: “Máquina parada ou em funcionamento, pela leitura de dois sensores?”.

Figura 14 – Exemplos de análise gerada por algoritmo de classificação Kernel SVM



Fonte: Elaborada pelo autor

No gráfico da figura, o eixo X representa o valor lido pelo sensor A e o eixo Y representa o valor lido pelo sensor B. Da interpolação dessas variáveis tem-se os pontos vermelhos e verdes, que representam os valores reais utilizados para treinar o algoritmo.

O resultado gerado no algoritmo são as áreas verde (produzindo) e vermelha (parada), indicando um comportamento previsto para novos valores dos sensores reais. Por exemplo: o sensor A lendo um valor de -1,75 e o sensor B lendo um valor de 0,75, prevê-se uma parada de máquina.

Logo, de acordo com os dados utilizados para treinar o algoritmo, valores menores que -0,5 no eixo X e menores que 1,2 no eixo Y preveem paradas de produção.

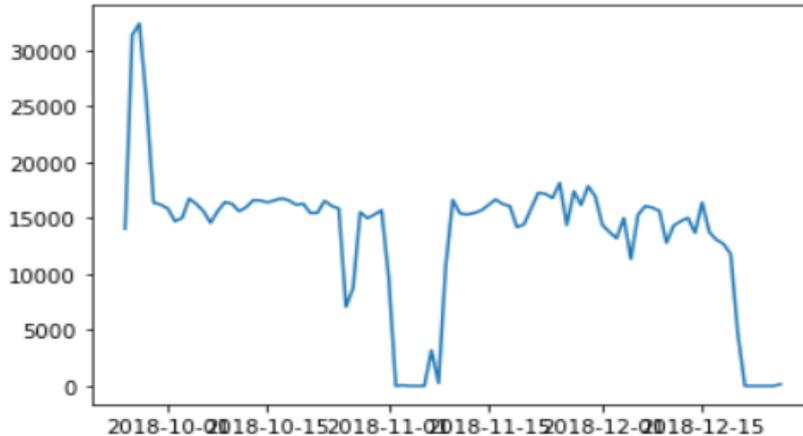
3.5.3 Modelos de séries temporais

Nos algoritmos de séries temporais, procura-se responder a perguntas do tipo: “Qual a tendência no tempo?” ou “Qual o comportamento sazonal?”.

No exemplo da figura 15, foram utilizados valores de referência para analisar o comportamento de um sensor, utilizando a biblioteca *Python seasonal_decompose*, para

prever: “Em quais limites de tendência a máquina pode ter problemas de manutenção?”.

Figura 15 – Exemplos de análise gerada por algoritmo de séries temporais

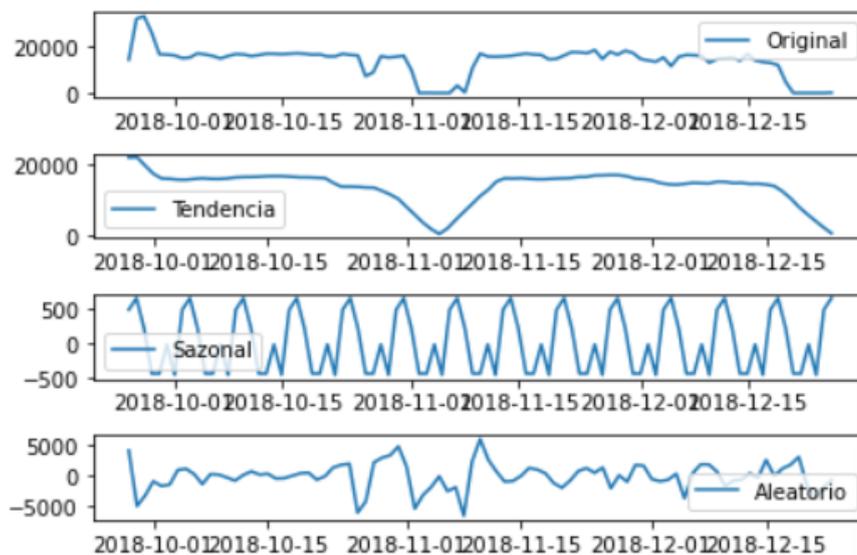


Fonte: Elaborada pelo autor

No gráfico estão representados no eixo Y, os valores lidos pelo sensor, e no eixo X, o tempo decorrido.

Os resultados apresentados pelo algoritmo são, além do gráfico original, os três novos gráficos mostrados na figura 16. Nesse caso, a análise apresenta condições diferentes de interpretação.

Figura 16 – Decomposição dos elementos de uma série temporal



Fonte: Elaborada pelo autor

No segundo gráfico pode-se observar a “tendência” de comportamento dos valores, geralmente sob o conceito de média móvel, para prever o comportamento dos valores novos, com base nos valores passados. Dessa forma, uma linha de tendência linear mostra que algo está aumentando ou diminuindo a uma taxa constante (VELÁSQUEZ et al., 2022, tradução nossa).

No terceiro gráfico pode-se observar um componente chamado de “sazonalidade”, que identifica o comportamento repetitivo dos valores da variável analisada, de acordo com

um período também repetitivo. Por exemplo, o valor se comporta de uma forma no verão e de outra forma no inverno, todos os anos.

O quarto gráfico não contém dados pertinentes para serem analisados.

De posse da informação de uma tendência, o gestor de manutenção pode verificar o comportamento de uma variável fora da normalidade, podendo programar atuações de manutenção de preventiva. Com a informação de sazonalidade é possível ao gestor validar situações previstas ou imprevistas, dependendo do período no tempo.

3.6 Etapa 6 - Testes realizados

Dos recursos aplicados nesse projeto, o resultado preditivo de quebras em equipamentos é o mais relevante. Além da possibilidade de anteceder um diagnóstico negativo de funcionamento em uma máquina, os esquemas de sensorização aplicados foram capazes de diagnosticar: falhas por vida útil de componentes, consumos de insumos, correlação entre equipamentos similares etc.

Dentre as variáveis analisadas, podem ser citadas: vibração e temperatura em motores, pressão diferencial de ar comprimido, fluxo de consumo de vapor, análise *online* de particulado, análise *online* de água em óleo hidráulico, temperatura em painéis elétricos etc.

1 RESULTADOS E DISCUSSÕES

Dentre as empresas do setor farmacêutico, automobilístico, autopeças, cosméticos, serviços de manutenção, química, educação, entre outras, atendidas pela instalação desse sistema, durante o período de 2018 a 2020, podem-se destacar os seguintes resultados:

- a) Identificação preditiva do aumento da temperatura em painéis elétricos, causados por falha no sistema de ar-condicionado, evitando queima dos componentes eletrônicos de controle da automação das máquinas;
- b) Monitoramento mais eficiente da vida útil do sistema de filtragem, através do sensor de saturação do filtro. Acompanhando a duração do sinal do filtro saturado, foi possível identificar a maior ou menor saturação do filtro. Dessa forma, foi reduzida a quantidade de peças compradas para o almoxarifado de manutenção, pela previsibilidade gerada.

Na figura 17, são apresentadas informações exemplificando os relatórios de gestão de manutenção, para avaliação do gestor com relação ao desempenho das atividades realizadas:

Figura 17 – Exemplo de relatório de índices de gestão de manutenção

Tempo Total de Produção								
	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto
	400 hora(s)	3000 hora(s)	600 hora(s)	600 hora(s)				

MTBF - MTTR - Disponibilidade								
	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto
MTBF	199.88 hora(s)	133.19 hora(s)	99.85 hora(s)	49.85 hora(s)	34.54 hora(s)	113.85 hora(s)	144.76 hora(s)	118.5 hora(s)
MTTR	0.12 hora(s)	0.14 hora(s)	0.15 hora(s)	0.15 hora(s)	1.83 hora(s)	1.54 hora(s)	5.24 hora(s)	1.5 hora(s)
Disponibilidade	99.94%	99.89%	99.85%	99.7%	94.97%	98.67%	96.51%	98.75%

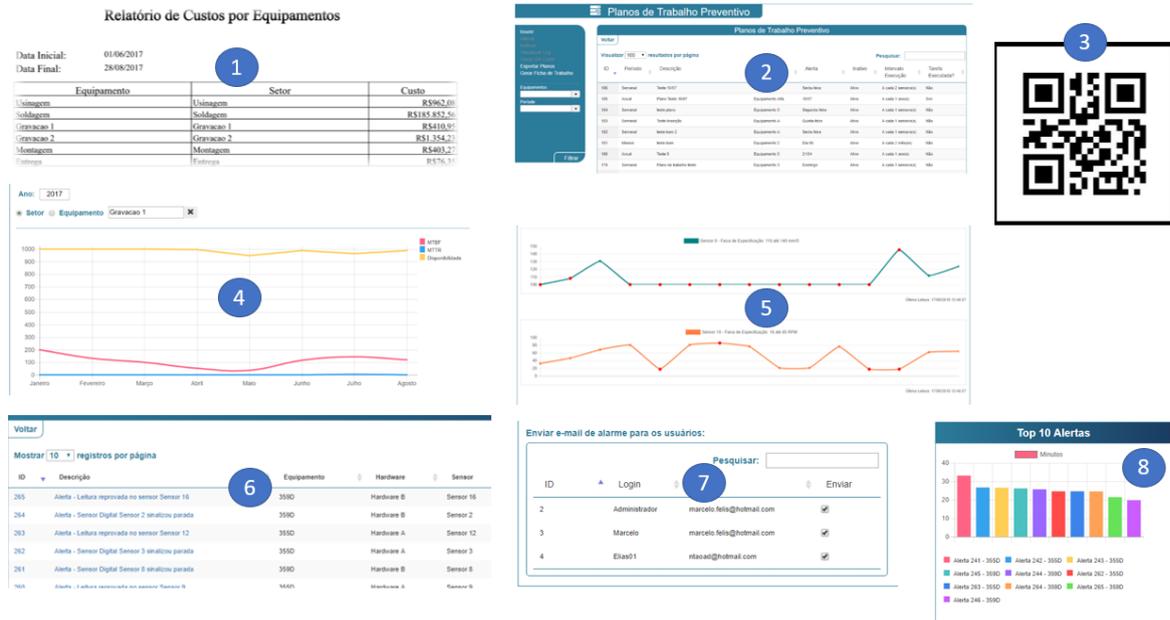
Quantidade de Eventos								
	Janeiro	Fevereiro	Março	Abril	Maió	Junho	Julho	Agosto
Corretiva	2	3	4	8	11	26	4	5
Preventiva	2	4	2	4	1	33	2	1

Fonte: Elaborada pelo autor

Dentre as funcionalidades desenvolvidas, a solução de software nesse projeto é composta pelas características descritas abaixo e mostradas na figura 18:

- Geração de relatórios *online* de manutenção corretiva (1);
- Programação com periodicidade variável as manutenções preventivas (2);
- Utilização de código de barras bidimensional (*QR Code*) na identificação de tarefas e no local de manutenção (3);
- Acompanhamento dos índices MTBF, MTTR, e da disponibilidade do equipamento (4);
- Monitoramento em tempo real variáveis sensorizadas com IIoT em pontos críticos das máquinas (5);
- Alerta das ocorrências por limites, tendências e anormalidade nos dados coletados, entre outras funções que compõe as ferramentas de *Machine Learning* (6);
- Notificação dos eventos via e-mails (7);
- Disponibilização dos dados em aplicativo móveis *Android* através de *dashboards* para os usuários cadastrados no sistema (8).

Figura 18 – Funcionalidades de gestão de manutenção desenvolvidas no sistema



Fonte: Elaborada pelo autor

1.1 Análise dos custos

Entre os anos 2018 e 2020, que representam os anos da implantação do projeto nos clientes, foram alcançados os indicadores financeiros mostrados na figura 19.

Nos três primeiros anos, houve uma série de investimentos no desenvolvimento do projeto, representando um valor baixo de lucros antes de juros, impostos, depreciação e amortização, ou *Earnings Before Interest, Taxes, Depreciation and Amortization* (EBITDA).

Já a receita operacional bruta representa o valor das vendas que ocorreram nos três últimos anos de funcionamento da empresa, indicando um valor crescente exponencial após o desenvolvimento e validação do produto.

Figura 19 – Indicadores financeiros da empresa fornecedora de sistemas de manutenção

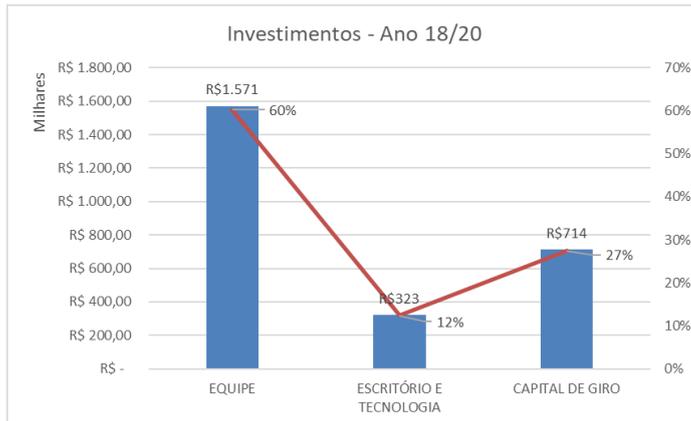
	2018	2020
RECEITA OPERACIONAL BRUTA		
Impostos sobre a receita bruta (R\$)		
RECEITA LÍQUIDA		
CUSTOS E DESPESAS		
EBITDA		

Fonte: Elaborada pelo autor

Na figura 20 temos a distribuição dos investimentos e custos operacionais ao longo dos anos de 2018 e 2020. Essa distribuição demonstra com bastante precisão a estrutura de gastos envolvidos no desenvolvimento de projetos com essas características.

Por tratar-se essencialmente de tecnologias com pouca integração entre si, até aquele momento, foi necessário o investimento massivo no capital humano, algo em torno de R\$1.571.000,00, gastos em pesquisas e integrações das tecnologias relacionadas.

Figura 20 – Distribuição dos custos entre Equipe, Escritório e Tecnologia e Capital de Giro



Fonte: Elaborado pelo autor

1.2 Análise dos resultados obtidos

Iniciada em 2016 como uma *startup* de base tecnológica, a empresa desenvolvedora do sistema foi incubada no Parque Tecnológico de Sorocaba, e foi acelerada em dois concursos distintos: da Federação das Indústrias do Estado de São Paulo (FIESP) e do Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE). Também recebeu apoio da Microsoft no programa *BizSpark* no valor de U\$120 mil, participou de feiras de exposição de tecnologia como a Feira Internacional de Máquinas-Ferramenta e Automação Industrial (EXPOMAFE) e a Feira Internacional de Máquinas e Equipamentos (FEIMEC), foi acelerada do programa *InovAtiva* do Ministério da Ciência, Tecnologia e Inovação (MCTIC), foi a primeira Startup incubada no UPLAB do SENAI de São Caetano do Sul, além de registrar uma patente no Instituto Nacional da Propriedade Industrial (INPI), mostrado na figura 21.

Figura 21 – Registro da Propriedade Intelectual no INPI



Fonte: Elaborada pelo autor

5 CONCLUSÃO

Os problemas enfrentados hoje em dia pela manutenção industrial, podem ser melhor resolvidos aplicando-se corretamente as ferramentas tecnológicas disponíveis.

Considerando-se o fato que uma equipe de manutenção deve contar com informações assertivas para a correta tomada de decisão nos reparos, existem atualmente condições tecnológicas convergentes para uma otimização da manutenção industrial sem precedentes.

Das capacidades tecnológicas atuais, há benefícios na aplicação de sensores para coleta frequente de dados, no armazenamento histórico desses dados, na correlação das atividades corretivas históricas e na análise do comportamento dos sinais ao longo do tempo.

De acordo com a TDGI Brasil (2020): “Segundo um levantamento da consultoria Aberdeen Research, a gestão correta da manutenção é capaz de promover um aumento da produtividade em 73%, diminuir os custos operacionais em 18% e cortar as despesas administrativas em 16%”.

Além dos resultados apresentados como a melhoria da manutenção preventiva nas empresas com a instalação do projeto, o que gera automaticamente uma redução nas paradas de máquinas e conseqüentemente aumento na produtividade e nos lucros da empresa, também devem-se considerar os resultados de ganhos intangíveis como:

- a) Aumento da eficiência e eficácia na resolução de problemas de manutenção;
- b) A sensorização adequada em máquinas possibilita a adoção de estratégias preditivas acompanhadas em tempo real;
- c) Geração de base de conhecimento histórico das atividades;
- d) Flexibilidade na distribuição e acompanhamento das tarefas de manutenção;
- e) Dados de manutenção bem armazenados e analisados;
- f) Gestão otimizada de peças de reposição e otimização de custos de almoxarifado de manutenção;
- g) Acompanhar o índice MTTR, relativo à performance dos técnicos de manutenção em relação aos reparos, favorece a identificação da necessidade de atualização através de treinamentos técnicos;

Outro ponto a ser considerado, foi que a *startup* investiu bastante no desenvolvimento tecnológico entre 2017 e 2020 anos, para que o lucro com a instalação da solução patenteada só viesse em 2020, passando assim três anos no vermelho. Isto vem mostrar a persistência, a adaptabilidade e a inovação que uma *startup* precisa ter, para transformar um projeto em um produto/solução inovadora e começar a lucrar com ela.

REFERÊNCIAS

ALABADI, M.; HABBAL, A.; WEI, X. Industrial internet of things: requirements, architecture, challenges, and future research directions. **IEEE Access**, v. 10, 2022. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9802088>. Acesso em: 25 out. 2022.

ASHKATORAB, V.; TAGHIZADEH, S. R.; ZAMANIFAR, Dr. K. A survey on cloud computing and current solution providers. **International Journal of Application or Innovation in Engineering & Management (IJAIEM)**, v. 1, n. 2, p. 226-233, 2012. Disponível em: <https://www.ijaiem.org/volume1Issue2/IJAIEM-2012-10-31-074.pdf>. Acesso em: 10 dez. 2022.

ASSOCIAÇÃO BRASILEIRA DE MANUTENÇÃO - ABRAMAN. Documento nacional. *In*: CONGRESSO BRASILEIRO DE MANUTENÇÃO, 28; MUNDIAL DE GESTÃO DE ATIVOS, 5. Salvador, Bahia.: ABRAMAN, 2013. CD-ROM.

DZAFERAGIC, M.; MARCHETTI, N.; MACALUSO, I. Fault detection and classification in industrial iot in case of missing sensor data. **IEEE Access**, v. 9, n. 11, p. 8893-8900, 2021. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9552963>. Acesso em: 15 jun. 2022.

EYADA, M. M.; SABER, W.; EL GENIDY, M. M.; AMER, F. Performance evaluation of iot data management using mongodb versus mysql databases in different cloud environments. **IEEE Access**, v. 8, p. 110656-110668, 2020. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9116940>. Acesso em: 11 nov. 2022.

LINS, R. G.; GIVIGI, S. N. Cooperative robotics and machine learning for smart manufacturing: platform design and trends within the context of industrial internet of things. **IEEE Access**, v. 9, p. 95444-95455, 2022. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9475965>. Acesso em: 10 nov. 2022.

OTANI, Mario; MACHADO, Waltair Vieira. A proposta de desenvolvimento de gestão da manutenção industrial na busca da excelência ou classe mundial. **Revista Gestão Industrial**, v. 4, n. 2, 2008. Disponível em: <http://dx.doi.org/10.3895/s1808-04482008000200001>. Acesso em: 27 jun. 2022.

PROJECT MANAGEMENT INSTITUTE - PMI. **Guia PMBOK**. 6. ed. Project Management Institute, 2017.

RASCHKA, Sebastian; PATTERSON, Joshua; NOLET, Corey. Machine learning in python: main developments and technology trends in data science, machine learning, and artificial intelligence. **MDPI**, v. 11, n. 4, 2022. Disponível em: <https://www.mdpi.com/2078-2489/11/4/193>. Acesso em: 10 dez. 2022.

TDGI BRASIL. **6 principais indicadores de manutenção para indústrias e empresas**. 11, Agosto de 2020. Disponível em: <https://tdgibrasil.com/indicadores-de-manutencao>. Acesso em: 14 set. 2022.

VELÁSQUEZ, D. et al. A hybrid machine-learning ensemble for anomaly detection in real-time industry 4.0 systems. **IEEE Access**, v. 10, 2022. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=9813703>. Acesso em: 05 mai. 2022.

VERIS INDUSTRIES. Different types of analog sensors & how to choose one. **Blog Veris**. Tualatin, 05 outubro 2021. Disponível em: <https://blog.veris.com/choosing-analog-signal-types-for-industrial-sensors-0-10v-or-4-20ma>. Acesso em: 05 out. 2022.

XU, H.; YU, W.; GRIFFITH, D.; GOLMIE, N. A survey on industrial internet of things: A cyber-physical systems perspective. **IEEE Access**, v. 6, 2018. Disponível em: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8558534>. Acesso em: 10 nov. 2022

AGRADECIMENTOS

Sou profundamente grato a Deus, pelas oportunidades de evolução e desenvolvimento, e à minha família por sua incessante contribuição para o meu aprendizado nesta vida.

Agradeço também aos excelentes professores do Curso MBA - Gestão de Projetos Aplicados à Inovação na Indústria 4.0 da Faculdade SENAI de Tecnologia Mecatrônica.

Agradeço aos meus colegas da turma T02 do curso, pelas contribuições de conhecimentos e experiências.

E finalmente agradeço em especial à minha Mãe, pelo amor incondicional, e ao meu Pai, exemplo de superação, nos encontraremos em breve no plano maior.

SOBRE OS AUTORES

i ELIAS AOAD NETO (ALUNO)



Possui graduação em Engenharia de Controle e Automação pela Universidade Paulista (2016), Tecnologia Mecatrônica (2004), especialização em redes industriais no Canadá (2006) e atualmente cursando pós-graduação MBA em Gestão de Projetos em Indústria 4.0 (2022) pela Faculdade SENAI de Tecnologia e Mecatrônica. Tem -experiência no desenvolvimento de projetos de Automação e TI industrial utilizando Robótica, CLPs, IIoTs, Servidores, CNCs e redes industriais, além de supervisão de equipes de manutenção industrial. Endereço para acessar este CV:

<http://lattes.cnpq.br/5708699412649367>

ii THIAGO TADEU AMICI (Orientador)



Ministra aulas na pós-graduação de Indústria 4.0 nas modalidades presencial e EAD, no MBA de Gestão de Projetos aplicados a inovação em Indústria 4.0 e nas graduações em Engenharia de Controle e Automação, em Tecnologia em Mecatrônica e Tecnologia em Análise e Desenvolvimento de Sistemas na Faculdade SENAI de Tecnologia Mecatrônica. Assessora também o Instituto SENAI de Tecnologia Metalmeccânica em projetos industriais com foco na Indústria 4.0, onde desenvolveu inúmeros projetos como integrador de relevância nacional e internacional. Tem experiência na área de Engenharia Elétrica, Automação Industrial, Mecatrônica, Robótica e Indústria 4.0. Experiência internacional na aprovação de linha de produção (Cavemil) em Milão na Itália e sua instalação no Brasil. Endereço para acessar este CV:<http://lattes.cnpq.br/9165856219131658>

iii DANIEL CAMUSSO (Banca)



Mestrando Profissional pela Universidade de Taubaté - UNITAU (previsão de término 2021). Pós-Graduado em Indústria 4.0 pela Faculdade SENAI de Tecnologia Mecatrônica. Pós-Graduado em Engenharia Automobilística pela Faculdade de Engenharia Industrial - FEI (2000). Aperfeiçoamento em CAD/CAM/CAE pela Dassault Systèmes em Paris - França. Graduado em Engenharia Mecânica Plena pela FEI (1996). Atualmente é docente no curso Técnico em Mecatrônica pela Escola SENAI Armando de Arruda Pereira. Foi docente do curso Superior "Tecnologia Mecatrônica Industrial" pela Faculdade SENAI e do curso de "Pós-Graduação em Projetos, Manufatura e Análise de Engenharia. Também docente do curso de especialização de CAD/CAE para Engenheiros de Países da América Latina (Convênio Brasil JICA Japan International Cooperation Agency). Participação no projeto Bleriot, um trabalho colaborativo entre Brasil, França e Índia e apresentado em 2009 na Feira Internacional de Aviação em Le Borget (França. Possui experiência como engenheiro na área de desenvolvimento de novos projetos para a indústria automobilística, utilizando o software CATIA e NX. CV: <http://lattes.cnpq.br/7303249573994245>

iv DANIEL OTÁVIO TAMBASCO BRUNO (Banca)



Doutorando em Engenharia da Informação na Universidade Federal do ABC (2016), Mestre em Engenharia da Informação pela Universidade Federal do ABC (2013), Especialista em Banco de Dados pela Universidade de Ribeirão Preto (2007) e Especialista em Educação à Distância pela Universidade Paulista (2012). Possui graduação em Análise de Sistemas pela Universidade Paulista (2003). Revisor do Periódico IEEE Transactions on Medical Imaging. Co-editor, editor de área e revisor da Revista Brasileira de Mecatrônica. É Revisor do periódico ForScience do Instituto Federal de Minas Gerais. Atualmente é Técnico em Manufatura Digital e professor da Escola Senai "Eng. Octávio Marcondes Ferraz" e Professor de ensino superior na Universidade Paulista. Tem experiência na área de Inteligência Artificial, Desenvolvimento de Sistemas de Informação, Processamento de imagens, Implantação e Administração de sistemas Product Lifecycle Management (PLM), Segurança de redes e Internet das Coisas. CV: <http://lattes.cnpq.br/3491851270517427>